

Croatian Journal of Education
Vol.18; No.2/2016, pages: 583-606

Professional paper

Paper submitted: 2nd March 2014

Paper accepted: 16th November 2015

doi:10.15516/cje.v18i2.1003

Indicators of Study Success Related to Impact of University Students' Enrollment Status

Sonja Išlamović¹, Veljko Jeremić¹ and Srđan Lalić²

¹Faculty of Organizational Sciences, University of Belgrade

²Statistical Office of the Republic of Serbia

Abstract

Analyzing and determining patterns among indicators of academic success and their correlation to students' enrollment status can be a good foundation in the process of adapting and improving the curriculum of higher education institutions, according to students' characteristics. In this paper we analyzed variables (the completed study program, student's gender, type of previously finished secondary school and the region where they finished secondary school) and indicators of academic success (GPA and study time) and their dependence on the status of enrollment at university. The results of this research indicate that students who enrolled in the status of budget financing (SBF) achieve greater success in terms of GPA (higher GPA) and the average time required to complete the study (shorter average time of study) in comparison to students who enrolled in the faculty in the self-financing status.

Key words: *educational data mining; higher education; student performance; study success.*

Introduction

Improvement and modernization of the teaching process and teaching content through the concept of continuous, lifelong learning, is a necessity in the global business system that is increasingly based on technology. The use of modern technological resources and teaching aids, as well as the adjustment of teaching content to students, in order to achieve better results in the adoption and application of knowledge, may represent a sound foundation for the development of contemporary concepts of education in the 21st century. In order to achieve this, it is necessary to detect, define and analyze existing patterns of behavior and students' learning.

Data Mining can be defined as a process that is based on the extraction, interpretation and use of information out of a broader set of data for decision-making (Suknović & Delibašić, 2010). Data mining in the field of education (Educational Data Mining - EDM), as a field of research, has developed in the last decade as a special area of application of techniques and tools for detecting regularities and correlations in the data (data mining), with the aim of analyzing the unique data types that appear in educational system for solving various problems in the educational and instructional improvement process (Romero & Ventura, 2007; Romero & Ventura, 2010). EDM is engaged in the development, research and application of methods for detection of regularities in data in the database in the field of education, which would otherwise be difficult or almost impossible to analyze and determine the dependency patterns of behavior and learning among students, primarily because of the large amount of data (Romero et al., 2010).

In this paper, the introductory part will present basic EDM concepts as well as the implementation impact of the Bologna Declaration on study success. Indicators of academic success will be analyzed in the central part of the paper (average grade achieved during the studies and average time of study) and their dependence on the status of enrollment in college (status funding from the budget or the status of self-financing). The final part of the paper defines guidelines for further development and adaptation of the system of higher education to students' needs.

Background and Related Works of Data Mining in University Education

EDM analyzes data from different types of information systems to support learning or education at colleges, universities and other academic or professional educational institutions that provide both traditional and modern forms and methods of teaching as well as non-formal learning (Romero & Ventura, 2007). The implementation of EDM is significant as data is not limited only to the student-teacher interaction or educational system (e.g. behavior, interactive exercises, oral answers), but can also contain data from the internal communication and collaboration of more students (e.g. working on projects, tracking activities within a forum, panel discussion), through administrative data (e.g. completed high school), sociodemographic data (Scheuer & McLaren, 2011). Baker and Yacef (2009) defined EDM as a new discipline, which deals with developing a method for exploring unique types of data that are coming from educational institutions and use of data mining for better understanding the behavior of students and their success in learning, i.e. knowledge acquisition. Campbell and Oblinger (2007) define EDM as academic analysis of data using statistical and data mining methods and techniques. Also, EDM can be seen as a methodology that will help schools (teachers and counselors for education) to detect high-risk and gifted students, at an early stage of study (Campbell & Oblinger, 2007). In a general sense and based on the previous definitions, EDM represents a research and scientific term that focuses on different types of data, collected within educational institutions, because academic data requires specific exploration and exploitation which are related to higher

education institutional effectiveness and student success issues, by defining suggestions for further education development. Research in this area has a focus on different aspects of the educational process: students, teachers, teaching materials, organization of teaching courses, etc. (Romero, 2007; Guruler et al., 2010; Kumar & Chadha, 2011).

Traditionally, academic researchers have used statistical models and methods in order to predict the success of the students. Today, there are many different approaches for classifying students and predicting their grades. Nebot et al. (2006) and Kotsiantis (2011) applied combinations of a few machine learning and classification techniques for determining the correlation between data. Minaei-Bidgoli & Punch (2003) used genetic algorithms, while Beck & Woolf (2000) applied methods of linear regression. Additionally, Flitman (1997) applied and compared Artificial Neural Network - ANN, Logistic Regression and Multiple Discriminate Analysis techniques in order to predict individual subject performance for each student, and results show that neural networks are far superior than traditional statistics and regression techniques. Gonzalez & Des Jardins (2002) tried to predict the success of students, using the linear regression and ANN models. The results of their research point that models of logistic regression do not predict behavior of students equally well as the ANN models. Thomas & Hass (2001) compared the performance of the three different techniques of data mining for predicting students' behavior: ANN, cluster algorithms and decision trees, where the model based on ANN gave the best results.

Over the last few years several studies in detecting principles in students' data have been conducted in Serbia with the aim of predicting and improving students' success (Gerasimović et al., 2011; Išljamović et al., 2012; Jovanović et al., 2012; Vukićević et al., 2012). The next section will describe the results of the analysis of successful studying at the Faculty of Organizational Sciences after the implementation of the Bologna Declaration.

Educational Data Mining at the Faculty of Organizational Sciences

Academic education holds a key role in a country's modernization and in being competitive. Education and the development of human resources are becoming increasingly important concepts, by which they can be determinants of success in business and in society as a whole. It can be said that the new social elite is coming from academic circles with the aim to stabilize and improve the overall state of the economy and society. Although academic education based on the principles has been presented in countries of the European Union for many decades, its implementation within the Balkan countries started in 2001. In Serbia, the institutions of higher education began in 2003 with the introduction and implementation of the Bologna Declaration, and many improvements in the educational process at universities have been recorded since then. Parallel to the adoption of the Bologna Declaration, universities and faculties in Serbia have modernized scientific and educational programs in order to adapt to the changes, to new scientific knowledge and current market trends as soon

as possible, focusing on continuous monitoring of educational needs. The number of graduates has increased by 16% after the implementation of the Bologna Declaration, while the average GPA increased from 8.13 ± 0.2884 for non-Bologna students on the 8.42 ± 0.3346 for students who have studied by Bologna Declaration (Statistical Office of the Republic of Serbia, 2011). The average duration of study was reduced from 6.45 to 5.09 years at the undergraduate level studies after the introduction of the Bologna Declaration (Išljamović et al., 2012). The performances of the academic success of the first five student generations that studied under the Bologna Declaration at the Faculty of Organizational Sciences will be presented in this paper.

Study Success at the Faculty of Organizational Sciences

At the Faculty of Organizational Sciences, University of Belgrade, the process of implementation of the Bologna Declaration commenced immediately after the decision on its implementation brought by the University of Belgrade, and the first generation of students were enrolled in the 2004/2005 academic year. This research covers the first five generations of students who have been registered in accordance to the principles of higher education implemented by the use of the Bologna Declaration, who had completed their studies by November 2013. In this time frame more than 60% of enrolled students have graduated, achieving an overall Grade point average (GPA) of 8.63 and the average time of study of almost 5 years.

The analysis of student success (GPA and average time of study), in a sample of 1012 graduates who enrolled into the first year of undergraduate study in the state-funding status and 775 graduate students who enrolled into the first year of undergraduate study in the self-financing status, was performed using the independent samples t-test (assumptions of t-test such as normality and homogeneity of variance have been checked with Kolmogorov-Smirnov and Levene test). The mentioned test was used to determine statistical significance of performance indicators between graduates whose studies have been funded from the state budget or the students who financed their own tuition. On the scale of significance $p < 0.05$ and certainty $P > 95\%$ a statistically significant difference was determined in terms of average study time and GPA of graduates from different status of enrollment in the first year of undergraduate study (the status of budget financing, hereinafter referred to as SBF or self-financing status, hereinafter referred to as SFS).

1. GPA for SBF graduates was 8.5777 ± 0.6520 , while the SFS graduates' GPA achieved during the studies was 8.0698 ± 0.5589 ($t = 17.335$, $p < 0.01$);
2. The average time of study of SBF graduate students was 4.8547 ± 0.9307 years, while SFS graduates completed their university study in an average of 5.2232 ± 1.0857 years ($t = 7.713$, $p < 0.01$).

Based on these results, it can be concluded that there is a statistically significant difference between graduates who have studied as state financed students (SBF) and self-financing students (SFS) in terms of the grade point average (GPA) and duration

of study time. According to the performed analysis, students who were in the status of state financing achieve better results during the study, both in terms of achieving a higher GPA and in completing their study program in a shorter time.

Comparative Analysis of the Enrollment Status at Faculty and Variables that Affect the Study Success

The following part of the paper will present the research of the comparative analysis of the success achieved in terms of GPA and average time of study considering the success of graduates studying at the Faculty of Organizational Sciences and their enrollment status (SBF or SFS). The analysis of study success indicators will be carried out according to the completed study program, student's gender, type of previously completed secondary school and the region where they completed secondary school.

At the Faculty of Organizational Sciences, during enrollment in the first year of undergraduate studies students choose one of two study groups: Information Systems and Technology (IST) or Management and Organization (MN). Along with the analysis of data, depending on the status of enrollment, it can be concluded that there is a significant difference in the number of students in each program of study, where the largest number of SBF graduates (566 students) completed the IST study program. This represents 72% of the graduates who completed that study program and 31.7% in relation to all graduates (see Figure 1a). At the same time, graduates with the SFS enrollment status who completed the MN study program account for 55% of the students that completed that study program. In terms of GPA, students with MN study programs who were in the SBF enrollment status achieved the best average grade (GPA 8.61), followed by graduates of the IST study program also in the SBF status (GPA 8.55). When it comes to graduates with the SFS enrollment status, better results are achieved by students in MN study programs in terms of GPA (8.13), and somewhat lower success is evident among students in the IST study program (GPA of 7.92) (see Figure 1b).




Figure 1. Study success in relation to enrollment status at the faculty and study program by (a) the number of students, (b) GPA, (c) average time of study

In terms of the average time of study, graduates of the IST and MN study program with the SBF status completed their studies in less than five years, that is 4 years and 8 months for students in the MN study program, and 4 years and 10 months for students in the IST study programs. For students with the SFS enrollment status, the average graduation time is over 5 years, where the average time of study is the longest for students in the IST study program (5 years and 4 months), and somewhat less for students in the MN study program (5 years and one month). Graduates of the IST program of study with the SFS enrollment status present the least numerous category by number of students, but have the lowest GPA and the longest average time of graduation, while the SBF graduates of the MN study program have the highest GPA and the shortest average time of graduation.

Depending on the status of enrollment in the first year of undergraduate studies, students of both genders who have enrolled with the SFS status, have achieved inferior results compared to their colleagues who entered the first year in the SBF status (see Figure 2). Female students, in both enrollment statuses, have better results (SFS: GPA - 8.18, average time of study - 5.08; SBF: GPA - 8.72, average time of study - 4.66), compared to male colleagues who, on average, achieved lower scores (SFS: GPA - 7.94, average time of study - 5.30; SBF: GPA - 8.39, average time of study - 4.99), with a statistical significance of $p < 0.05$. Furthermore, students who enrolled in the SBF status, regardless of gender, achieved a shorter than the average time of study than students who enrolled in the SFS status. In way of GPA, SBF students achieved significantly better grades than students in the first year of undergraduate study enrolled in the SFS status (see Figure 2).




Figure 2. Study success in terms of students' gender and enrollment status by (a) the number of students, (b) GPA, (c) average time of study

The majority of the graduates of the Faculty of Organizational Sciences, 75% of the total number of graduates, had previously graduated from grammar school. About 20% of graduates came from business and technical secondary schools, and those are the graduates who have previously completed secondary business schools - 7%, secondary electro-technical schools - 6.86% and secondary technical schools - 5.68% of the total number of graduates, and the remaining 5.5% of graduates come from other secondary schools or are secondary school graduates from abroad. For

the selection of students who will enroll in the SBF status, the average score from secondary school is the most important along with points from the entrance exam. So, further in this paper we will present the analysis and impact of those variables on study success.

At the time of enrollment into a faculty, one of the most important variables which determine the status of student enrollment can be ascertained by success in secondary school represented through the average mark achieved during secondary school (which takes the value 4 of the average grades at the end of each school year). As can be seen from Figure 3a, the SBF status is acquired by students who have had great success during secondary school (average grade in high school is over 4.5), while SFS status is acquired by those students who have very good success in secondary school (average grade in secondary school is between 4 and 4.5). Regardless of the enrollment status, students who previously completed secondary mechanical engineering school have had the highest average rating (average of four years of secondary school), 4.82 and 4.44 on the SBF status and SFS status respectively. The students in the SBF status, according to their success in secondary school, are those students from secondary mechanical engineering school, followed by students from secondary technical schools (success in secondary school - 4.64), and students from grammar schools and secondary electro technical school (success in secondary school - 4.62, in both types of secondary school). Students in the SFS status, according to success in secondary school, are students coming from secondary business schools, where the GPA of - 4.39 is the best result, followed by students from secondary technical schools (success in secondary school - 4.20) and grammar schools (success in secondary school - 4.13) (see Figure 3a).




Figure 3. Relation between enrollment status and type of secondary school by
(a) success in secondary school and (b) points on the entrance exam

Another important variable that affects enrollment at a faculty is defined through the number of points that a student achieves on the entrance exam (ranging from 1 to 100 points). In the entrance test, the best average performance was achieved by students who had previously finished grammar schools (an average of 71.96 points on the entrance exam), followed by graduates who had completed secondary technical schools (an average of 71.03 points on the entrance exam) and secondary machine

engineering schools (an average of 69.74 points on the entrance exam). Secondary school students who achieved on average over 60 points on the entrance exam had the opportunity to enroll at faculty in the SBF status (see Figure 3). Students who enrolled in SFS status, are those with good results achieved in previously completed grammar schools (an average of 41.26 points on the entrance exam) and secondary electro technical schools (an average of 39.36 points on the entrance exam) (see Figure 3), which is almost twice the lower result compared to students who enrolled in the SBF status.

In terms of the number of students coming from different geographical regions and districts who enroll at the Faculty of Organizational Sciences, we can say that the great majority of students come from the Belgrade region, representing 54% of the total number of graduates. They are followed by 25% of students from Šumadija and Western Serbia (in particular students from Zlatibor, Raška and Morava district), while 5% of graduates are students who completed their secondary schools abroad (Montenegro, Bosnia and Herzegovina, Canada...). The best success on entrance exam is achieved by graduates from Southern and Eastern Serbia (the average number of points on the entrance exam is 61.43), who also have the best average GPA in studying (8.47). With respect to the average time of study, the shortest average time was achieved by graduates from Kosovo and Metohija, for both overall and SBF students, with the shortest time of graduation (4 years and 2 months), (see Figure 4). Students from Šumadija or foreign countries have the longest average study time in the SBF status. When it comes to students in the SFS status, the longest study time is evident among graduates from Vojvodina (5 years and 5 months) and the shortest average time of studies is evident among graduates from the Belgrade region (5 years and 1 month) (see Figure 4).




Figure 4. Influence of region of secondary school on average time of study by enrollment status

The Impact of College Enrollment Status on Study Success

In order to define regularities in the data about graduates who enrolled into the college in the 2004/2005 academic year and completed it by November 2013, using

the concept of Binomial Logistic Regression, a statistical significance was determined between the status of faculty enrollment and dependent variables that indicate students' success in secondary school, region and type of finished secondary school, the number of points on the entrance exam, the type of study course, the average mark achieved during the study (GPA) and the average time of study ($\chi^2_{(5, N=1787)}=1318.606, p<0.01$). In examining the dependency and impact of the student success at faculty, out of the initial eight variables (region of secondary school, type of secondary school, success in secondary school, points on the entrance exam, program of study at the faculty, GPA, average time of study and student's gender), five variables were isolated through the 4-step regression models as having a significant correlation in comparison to the status of college enrollment and student success in college. The variable overview and their significance are presented in Table 1. While using the Binomial Logistic Regression (minimum number of cases per independent variable is fully met, we also checked for normality, linearity and homogeneity of variance although there was no need for it as stated by Hosmer et al., 2013), for the observed set of variables, 3 variables showed that no statistical significance existed and were therefore excluded from further analysis in the following order, respectively: student gender ($p=0.544$), the region of finished secondary school ($p=0.344$), type of previously finished secondary school ($p=0.428$).

Table 1

Illustration of significant variables in Binomial Logistic Regression model for predicting performance of studying success depending on the enrollment status

Results from 4th (final) step	B	S.E.	Sig.	Exp(B)
<i>points on entrance exam</i>	0.130	0.007	0.000	1.139
<i>GPA</i>	0.873	0.169	0.000	2.395
<i>success in secondary school</i>	1.003	0.188	0.000	2.726
<i>average time of study</i>	0.460	0.094	0.000	1.585
<i>study program</i>	-0.558	0.160	0.000	0.572

As can be seen from Table 1 above, the first four variables (points in the entrance exam, GPA, success in secondary school, average time of study) are important for determining the success of study of SBF students ($\text{Exp}(B) > 1$), while the variable of study program has a significant impact in defining SFS student success.

In further work, a CATPCA (Principal Components Analysis for Categorical Data) analysis was performed in order to find an adequate way to merge the information that has been contained in the original variables into a smaller set of new composite variables that are assumed to be an essentially representative subset of the original variables, with a minimum loss of information. In data about the success of five generations of students studying at the Faculty of Organizational Sciences, using Factor analysis, three or four groups of variables have been defined in a significant way affecting the overall success of the study depending on the status of faculty enrollment, which the results in Table 2 refer to.

Table 2

Results of CATPCA analysis by students' enrollment status

Variable\ variance proportion %	SBS – enrollment status of budget financing				SFS - self-financing enrollment status		
	Group of variable subset				Group of variable subset		
	1	2	3	4	1	2	3
	26.82	17.28	13.42	12.55	25.26	16.90	13.28
average time of study	0.801				0.770		
student's gender		0.701				0.733	
points on the entrance exam	0.557				0.643		
GPA	0.834				0.771		
region of secondary school				0.874			0.475
success in secondary school				0.519	0.531		
program of study		0.767				0.763	
type of secondary school			0.873				0.781
	Kaiser-Meyer-Olkin=0.617, p<0.01				Kaiser-Meyer-Olkin=0.607, p<0.01		

For SBF students there are segregate 4 subset variables, while SFS students were allocated 3 subsets of variables which in a significant way determine the overall success of students. In the second group of important variables, the identical group of variables has been selected in both groups of students according to the status of enrollment at faculty. For SBF students within the most significant subset of variables (the first subset of variables) are the following variables: average time of study, points on the entrance exam and GPA. For students with SFS enrollment status the first and most important subset of variables comprises the following variables which have been consolidated: average time of study, points on the entrance exam, GPA and success in secondary school, and those results indicating the similarity of the variables, that determine the success of study depending on the status of enrollment in both groups.

In the second group of variables, with respect to the SBF status of graduates enrolling into college, variables that allow the determination of study effectiveness are the following ones: student gender and program of study. While in the third group there is only a variable of secondary school type, and within the 4th group there is a subset of the variables related to the characteristics of students in secondary school (secondary school region, success in secondary school). The success of graduates with an SFS faculty enrollment status, in addition to the variables in the first subset, can be determined through variables: student gender and program of study in the second group of important variables, or by the third group of variables - region of secondary school and the type of secondary school.

Conclusion

In this paper, in the attempt to better organize collected data and information about students and their success in higher, university education, using DM techniques, we present the results relating to the possible impact of faculty enrollment status on

study success performance, especially in terms of GPA and average time of study. The research results indicate that there are differences in performance of study, i.e. success by students who enrolled into the faculty in the SBF or SFS status.

The analysis of research results indicates that students who enrolled in the SBF status achieve greater success in terms of GPA (higher GPA) and the time required to complete the study (shorter average time of study) in comparison to students who enrolled into the faculty as SFS students. The presumption that students are at the approximately same level of knowledge after graduation and when enrolling into college can serve as a potential indicator for improving higher education, as an additional commitment to improving the success of students enrolled in the SFS status. Students in the MN study program achieved better academic success, in terms of GPA and average time of study, compared to students in the IST study program, regardless of enrollment status. The shortest graduation time is observed among students from Kosovo and Metohija, and the best average grade is achieved by graduates from Southern and Eastern Serbia, while the greatest number of students came from the Belgrade region.

Future developments and research, firstly in terms of the advanced use of EDM concepts, will include integration of a large number of input variables, such as those that are directly related to studies, socioeconomic, and demographic data, their comparative analysis, and secondly in developing a model for predicting study success based on variables that were analyzed in this work.

Acknowledgement

This research is supported by projects of the Ministry of Education and Science of the Republic of Serbia, as a part of a project of technological development, project number ID III 47003.

References

- Baker, R. S. J. D., & Yacef, K. (2009). The state of educational data mining in 2009: a review and future visions. *Journal of Educational Data Mining*, 3–17.
- Beck, J. E., & Woolf, B. P. (2000). High-Level Student Modeling with Machine Learning. In G. Gauthier et al. (Eds.), *Intelligent Tutoring Systems, ITS 2000. Lecture Notes in Computer Science, Vol. 1839* (pp. 584-593). New York: Springer, Berlin Heidelberg. http://dx.doi.org/10.1007/3-540-45108-0_62
- Campbell, J., & Oblinger, D. (2007). *Academic analytics*. Washington, DC: Educause
- Flitman, A. M. (1997). Towards Analysing Student Failures: Neural Networks Compared With Regression Analysis and Multiple Discriminant Analysis. *Computers Ops Res*, 24(4), 367-377. [http://dx.doi.org/10.1016/S0305-0548\(96\)00060-3](http://dx.doi.org/10.1016/S0305-0548(96)00060-3)

- Gerasimović, M., Stanojević, L., Bugarić, U., Miljković, Z., & Veljović, A. (2011). Using Artificial Neural Networks for Predictive Modeling of Graduates' Professional Choice. *The New Educational Review*, 23(1), 175-188.
- Gonzalez, J. M., & DesJardins, S. L. (2002). Artificial neural networks: A new approach to predicting application behavior. *Research in Higher Education*, 43(2), 235 – 258. <http://dx.doi.org/10.1023/A:1014423925000>
- Guruler, H., Istanbulu, A., & Karahasan, M. (2010). A new student performance analysing system using knowledge discovery in higher educational databases. *Computers & Education*, 55(1), 247–254. <http://dx.doi.org/10.1016/j.compedu.2010.01.010>
- Hosmer, D., Lemeshow, S., & Sturdivant, R. (2013). *Applied Logistic Regression*. Wiley Series in Probability and Statistics. New York: John Wiley & Sons, Inc. <http://dx.doi.org/10.1002/9781118548387>
- Išljamović, S., Vukićević, M., & Suknović, M. (2012). Demographic influence on students' performance - case study of University of Belgrade. *TTEM - Technics Technologies Education Management*, 7(2), 648-660.
- Jovanović, M., Vukićević, M., Išljamović, S., & Suknović, M. (2012). Automatic evolutionary design of decision tree algorithm for prediction of university student success. *Stochastic Modeling Techniques and Data Analysis International Conference (SMTDA2012)*. Crete, Greece.
- Kotsiantis, S. B. (2011). Use of machine learning techniques for educational proposes: a decision support system for forecasting students' grades. *Artificial Intelligence Review*, 37(4), 331-344. <http://dx.doi.org/10.1007/s10462-011-9234-x>
- Kumar, V., & Chadha, A. (2011). An Empirical Study of the Applications of Data Mining Techniques in Higher Education. *International Journal of Advanced Computer Science and Application*, 2(3), 80–84.
- Minaei-Bidgoli, B., & Punch, B. (2003). Using Genetic Algorithms for Data Mining Optimization in an Educational Web-based System. *Genetic and Evolutionary Computation*, 2, 2252–2263. http://dx.doi.org/10.1007/3-540-45110-2_119
- Nebot, A., Castro, F., Vellido, A., & Mugica, F. (2006). Identification of Fuzzy Models to Predict Students Performance in an e-Learning Environment. In *The Fifth IASTED International Conference on Web-Based Education* (pp. 74-79). Puerto Vallarta, Mexico.
- Romero C., Ventura S., Pechenizky M., & Baker, R. (2010). *Handbook of Educational Data Mining*. Data Mining and Knowledge Discovery Series. Boca Raton, FL: Chapman and Hall, CRC Press. <http://dx.doi.org/10.1201/b10274>
- Romero C., & Ventura, S. (2007). Educational data mining: a survey from 1995 to 2005. *Journal of Expert System with Applications*, 1, 135–146. <http://dx.doi.org/10.1016/j.eswa.2006.04.005>
- Romero C., & Ventura, S. (2010). Educational data mining: a review of the state-of-the-art. *IEEE Trans SystMan Cybern C: Appl Rev*, 40, 601–618. <http://dx.doi.org/10.1109/TSMCC.2010.2053532>
- Scheuer, O., & McLaren, B. M. (2011). Educational data mining. In *The Encyclopedia of the Sciences of Learning*. New York, NY: Springer.

- Statistical Office of the Republic of Serbia (2011). *Statistical Yearbook for 2010*. /online/. Retrieved on 5th February 2013 from www.stat.gov.rs.
- Suknović, M., & Delibašić, B. (2010). *Poslovna inteligencija i sistemi za podršku odlučivanju [Business intelligence and decision support systems]*. Beograd: Fakultet organizacionih nauka.
- Thomas, J., Chongwatpol, J., Pengnate, F., & Hass, M. (2011). Data Mining in Higher Education: University Student Declaration of Major Data Mining in Higher Education, Omaha, Nebraska. In *Proceedings of the Sixth Midwest Association for Information Systems Conference, Omaha, May, 2011*.
- Vukićević, M., Išljamović, S., Jovanović, M., Delibašić, B., & Suknović, M. (2012). Primena neuronskih mreža za predviđanje uspeha studenata [The application of neural networks for prediction students' success]. In *Zbornik radova YU INFO 2012 - 18. Konferencija o informacionim i komunikacionim tehnologijama*, Kopaonik, Serbia.

Sonja Išljamović

Center for Business Decision-making
Faculty of Organizational Sciences
University of Belgrade
Jove Ilića 154, 11000 Belgrade, Serbia
sonjaisljamovic@gmail.com

Veljko Jeremić

Operational Research and Statistics
Faculty of Organizational Sciences
University of Belgrade
Jove Ilića 154, 11000 Belgrade, Serbia
jeremic.veljko@fon.bg.ac.rs

Srdan Lalić

Group for European Integration
Statistical Office of the Republic of Serbia
Milana Rakića 5, 11000 Belgrade, Serbia
srdjan.lalic@stat.gov.rs

Pokazatelji uspješnosti studiranja u korelaciji s tipom financiranja prilikom upisa na fakultet

Sažetak

Analiza i utvrđivanje uzoraka kod pokazatelja akademskog uspjeha i njihove korelacije u odnosu na tip financiranja prilikom upisa studenta na fakultet može predstavljati dobru početnu osnovu za prilagodbu i unapređenje nastavnoga plana i programa visokoškolske institucije, u skladu s karakteristikama studenata. U sklopu ovog istraživanja analizirane su osnovne varijable (studijski program fakulteta, spol studenta, tip prethodno završene srednje škole i područje u kojem je student završio srednju školu) te indikatori uspješnosti studiranja (prosječna ocjena na kraju studija i vrijeme potrebno za završetak studija) kao i njihova ovisnost o statusu studenta prilikom upisa na fakultet. Rezultati istraživanja upućuju na to da postoje razlike u pogledu ostvarenih dostignuća uspjeha studiranja i na to da studenti koji su na fakultet upisani u statusu državnoga subvencioniranja ostvaruju bolji uspjeh tijekom studiranja u pogledu ostvarene bolje prosječne ocjene studiranja (viša prosječna ocjena studiranja) i vremena potrebnog za završetak studija (kraće prosječno vrijeme završetka fakulteta) u odnosu na studente koji su upisani u statusu samofinanciranja.

Ključne riječi: izvedba studenta; otkrivanje zakonitosti u podacima iz područja edukacije; uspjeh studija; visokoškolsko obrazovanje.

Uvod

Modernizacija nastavnoga procesa i nastavnih sadržaja, kroz koncept cjeloživotnog učenja, neophodna je u svijetu globalnog poslovanja koje se temelji na tehnologiji i sve bržem tehnološkom razvoju. Upotreba tehnološki suvremenih sredstava i pomagala, kao i prilagođavanje nastavnog sadržaja studentima, kako bi se postigli što bolji rezultati usvajanja i primjene znanje, može predstavljati dobru osnovu za razvoj kontinuiranih i suvremenih koncepata obrazovanja u 21. stoljeću. Kako bi se sve navedeno postiglo, neophodno je detektirati, definirati i analizirati postojeće obrasce ponašanja i učenja učenika.

Otkrivanje zakonitosti u podacima (eng. *Data Mining*) može se definirati kao proces koji je zasnovan na izvlačenju, interpretiranju i korištenju informacija iz šireg skupa podataka, radi donošenja odluke (Suknović i Delibašić, 2010). Otkrivanje zakonitosti u

podacima iz područja edukacije (eng. *Educational Data Mining - EDM*) kao područje istraživanja razvilo se u posljednjih deset godina kao posebno područje primjene tehnika i alata otkrivanja zakonitosti u podacima s ciljem analiziranja jedinstvene vrste podataka koji se javljaju u obrazovnim sustavima, u svrhu rješavanja različitih obrazovnih problema i poboljšanje nastavnih procesa (Romero i Ventura, 2007; Romero i Ventura, 2010). Otkrivanje zakonitosti u podacima iz područja edukacije bavi se razvojem, istraživanjem i primjenom metoda za otkrivanje zakonitosti u podacima unutar baza podataka iz obrazovanja, a koje bi inače bile teško ili gotovo nemoguće analizirati te utvrđivati međuovisnost u obrascima ponašanja i učenja kod studenata, prije svega zbog velike količine podataka (Romero i sur., 2010).

U okviru ovog rada u uvodnome će dijelu biti predstavljeni osnovni koncepti otkrivanja zakonitosti u podacima iz područja edukacije, kao i utjecaji implementacije Bolonjske deklaracije na uspjeh studiranja. U središnjem dijelu rada bit će analizirani indikatori uspješnosti studiranja (prosječna ocjena ostvarena tijekom studija i prosječno vrijeme studiranja) i njihova ovisnost o statusu upisa na fakultet (status državnog subvencioniranja ili status samofinanciranja) te prikazani s pomoću studije slučaja s Fakulteta organizacijskih nauka, Sveučilišta u Beogradu. U zaključnome dijelu rada bit će definirane smjernice za daljnje unapređenje i prilagodbu visokoškolskog obrazovnog sustava shodno karakteristikama studenta.

Pregled područja i istraživanja u otkrivanju zakonitosti u podacima iz područja visokoškolskog obrazovanja

Otkrivanje zakonitosti u podacima iz područja obrazovanja (EDM) analizira podatke iz različitih vrsta informacijskih sustava za potporu učenju ili obrazovanju na fakultetima, sveučilištima i drugim akademskim ili profesionalnim obrazovnim institucijama koje pružaju tradicionalne i suvremene oblike i metode nastave kao i neformalno učenje (Romero i Ventura, 2007). Značajna je implementacija EDM-a gdje podatci nisu ograničeni samo na interakciju učenika s nastavnikom ili edukativnim sustavom (npr. ponašanje, interaktivne vježbe, usmeni odgovori) već mogu sadržavati informacije iz interne komunikacije i suradnje više učenika (npr. rad na projektnim zadacima, praćenje aktivnosti unutar foruma), preko administrativnih podataka (npr. završena srednja škola) i sociodemografske podatke (Scheuer i McLaren, 2011). Baker i Yacef (2009) definirali su EDM kao novu disciplinu koja se bavi razvojem metoda za istraživanje jedinstvene vrste podataka koji dolaze iz obrazovnih institucija i koristiti te metode za bolje razumijevanje ponašanje studenata i njihova uspjeha u učenju, tj. usvajanju znanja. Campbell i Oblinger (2007) definiraju EDM kao analitiku akademskih podataka korištenjem statističkih metoda i OZP-a. Također, EDM se može sagledati kao metodologija koja će pomoći fakultetima (nastavnom osoblju i savjetnicima za obrazovanje) u otkrivanju rizičnih i nadarenih studenata u ranoj fazi studiranja (Campbell i Oblinger, 2007). U općem smislu, a zasnivajući se na prethodnim definicijama, EDM predstavlja istraživački i znanstveni termin koji se

fokusira na različite vrste podataka koji se prikupljaju u okviru obrazovnih institucija, dok analitika akademskih podataka zahtijeva specifične podatke koji se odnose na visokoškolsku institucionalnu učinkovitost i pitanja uspješnosti studenata, prije svega u smislu definiranja smjernica za daljnji razvoj i unapređenje obrazovnog procesa i sustava. Istraživanja iz toga područja imaju fokus na različite aspekte edukativnog procesa: studente, nastavnike, nastavne materijale te organizaciju nastave itd. (Romero, 2007; Guruler i sur., 2010; Kumar i Chadha, 2011)

Tradicionalno, akademska istraživanja su se temeljila na korištenju statističkih modela i metoda s ciljem da se predvidi uspjeh studiranja. Danas postoji veliki broj različitih pristupa usmjerenih klasifikaciji učenika i studenata i predviđanju njihovih ocjena. U istraživanjima koja je provela skupina istraživača (Nebot i sur., 2006; Kotsiantis, 2011) primjenjivane su kombinacije modela temeljenih na konceptima strojnog učenja i tehnika klasifikacije s ciljem utvrđivanja korelacije u podacima iz područja edukacije. Minaei-Bidgoli i Punch (2003) su koristili genetske algoritme, dok su Beck i Woolf (2000) primjenjivali metode linearne regresije za predikciju uspješnosti studiranja. U istraživanju Flitmana (Flitman, 1997) primijenjene i uspoređene su tehnike i metode umjetnih neuronskih mreža, logističke regresije i višestruke diskriminativne analize s ciljem da se predvidi za svakog studenta uspjeh na svakom od predmeta. Istraživanje je pokazalo da su daleko najbolje rezultate dali modeli temeljeni na umjetnim neuronskim mrežama, pogotovo u odnosu na tradicionalne statističke i regresijske modele. Gonzalez i Des Jardins u svom su istraživanju predviđali uspjeh studiranja korištenjem modela temeljenih na regresijskoj analizi i umjetnim neuronskim mrežama, gdje rezultati upućuju na to da modeli linearne regresije ne mogu jednako dobro i precizno predvidjeti ponašanje studenata kao što je slučaj kod modela zasnovanih na umjetnim neuronskim mrežama (Gonzalez i Des Jardins, 2002). Thomas i Hass su usporedili performanse točnosti tri različite tehnike otkrivanja zakonitosti u podacima za predviđanje uspjeha i ponašanja studenata: umjetne neuronske mreže, algoritme klasteriranja i stabla odlučivanja gdje su se modeli temeljeni na umjetnim neuronskim mrežama pokazali kao najprecizniji (Thomas i Hass, 2001).

Posljednjih nekoliko godina u Srbiji je provedeno nekoliko istraživanja s ciljem otkrivanja zakonitosti u studentskim podacima te predviđanja i poboljšanja uspjeha studenata (Gerasimović i sur., 2011; Išlamović i sur., 2012; Jovanović i sur., 2012; Vukićević i sur., 2012). U sljedećem dijelu rada bit će predstavljeni rezultati analize uspješnosti studiranja na Fakultetu organizacijskih nauka Sveučilišta u Beogradu nakon implementacije Bolonjske deklaracije.

Otkrivanje zakonitosti u podacima iz područja edukacije na Fakultetu organizacijskih nauka Sveučilišta u Beogradu

Akademsko obrazovanje predstavlja jednu od ključnih uloga u procesu modernizacije jedne države i ostvarivanja konkurentске prednosti. Proces edukacije i razvoja ljudskih

resursa postaje sve važniji čimbenik i odrednica performanse uspješnosti kako poslovanja uopće tako i društva u cjelini. Može se reći da nova društvena elita upravo dolazi iz akademskih krugova s ciljem da stabilizira i unaprijedi cjelokupno stanje gospodarstva i društva. Iako je akademsko obrazovanje utemeljeno na postulatima Bolonjske deklaracije u zemljama Europske unije zastupljeno već više desetljeća, kod balkanskih zemalja taj je proces započeo 2001. godine. Visokoškolske obrazovne institucije u Srbiji su 2003. godine započele proces uvođenja i implementacije principa Bolonjske deklaracije i od tada su zabilježena mnogobrojna poboljšanja u edukativnom procesu na fakultetima.

Paralelno s usvajanjem Bolonjske deklaracije sveučilišta i fakulteti u Srbiji razvijali su i osuvremenjivali znanstveno-nastavne programe u cilju da se što prije prilagode promjenama, novim znanstvenim saznanjima i trenutnim tržišnim trendovima, fokusirajući se na kontinuirano praćenje obrazovnih potreba. Broj diplomiranih studenata povećan je za 16 % nakon primjene Bolonjske deklaracije, dok je prosječna ocjena studiranja rasla, od $8,13 \pm 0,2884$ za studente po nebolonjskim programima na $8,42 \pm 0,3346$ za studente koji su studirali po Bolonjskoj deklaraciji (Republički zavod za statistiku 2011). Prosječno vrijeme studija smanjeno je sa 6,45 na 5,09 godina na osnovnim razinama akademskih studija nakon uvođenja Bolonjske deklaracije (Išljamović i sur., 2012). Mogućnosti uspješnosti studiranja prvih pet generacija studenata po Bolonjskoj deklaraciji na Fakultetu organizacijskih nauka bit će predstavljene u nastavku rada.

Uspjeh studenata na Fakultetu organizacijskih nauka

Na Fakultetu organizacijskih nauka, Sveučilišta u Beogradu, proces uvođenja Bolonjske deklaracije započeo je odmah nakon donošenja odluke o njenoj provedbi od Sveučilišta u Beogradu, te je već u školskoj 2004./2005. godini upisana prva generacija studenata. Ovim istraživanjem obuhvaćeno je prvih pet generacija studenata koje su upisane shodno principima visokoškolske edukacije implementiranih primjenom Bolonjske deklaracije, a koji su studije završili do studenoga 2013. godine. U tom vremenskom intervalu više od 60 % upisanih studenata diplomiralo je, ostvarujući ukupnu prosječnu ocjenu od 8,63 (od maksimalne ocijene 10) uz prosječno vrijeme studiranja od skoro 5 godina.

Analiza uspjeha studenata (ostvarene prosječne ocjene studiranja i vremena potrebnog za završetak studija) na uzorku od 1012 diplomiranih studenata koji su na prvu godinu osnovnih akademskih studija upisani u statusu financiranja iz državne subvencije i 775 diplomiranih studenata koji su upisani u statusu samofinanciranja, realizirana je primjenom neovisnog T-testa (pretpostavke T-testa kao što su normalnost i homogenost varijance provjereni su primjenom Kolmogorov-Smirnov i Levene testa) za utvrđivanje statističke značajnosti kod indikatora uspješnosti između studenata diplomskog studija koji su upisani u statusu financiranja iz državne subvencije i statusa samofinanciranja. S pragom značajnosti $p < 0,05$ i sigurnošću $P > 95$ % utvrđeno je da

razlika u pogledu ostvarene prosječne ocjene i vremena studiranja kod diplomaca s različitim statusom upisa (status financiranje iz državne subvencije u daljnjem tekstu bit će referenciran kao SBF i status samofinanciranja koji će biti referenciran kao SFS) je statistički značajna:

- Prosječna ocjena je tijekom studiranja kod SBF diplomaca $8,5777 \pm 0,6520$, dok je kod SFS diplomaca vrijednost prosječne ocjene ostvarene tijekom studiranja $8,0698 \pm 0,5589$ ($t = 17,335$, $p < 0,01$);
- Prosječno vrijeme studiranja je kod SBF diplomaca $4,8547 \pm 0,9307$ godina, dok su SFS diplomci fakultet u prosjeku završavali za $5,2232 \pm 1,0857$ godina ($t = 7,713$, $p < 0,01$).

U skladu s tim rezultatima može se inicijalno zaključiti da postoji statistički značajna razlika kod diplomaca koji su studirali u statusu financiranje iz državne subvencije (SBF) i statusu samofinanciranja (SFS) u pogledu ostvarene prosječne ocjene na kraju studija i vremena provedenoga na studijama. Studenti koji su imali status financiranje iz državne subvencije ostvarivali su bolji uspjeh tijekom studiranja, kako u ostvarenim višim prosječnim ocjenama tako i u kraćem vremenu potrebnom za završetak studija, u skladu s analizom.

Komparativna analiza statusa upisa na fakultet i varijabli koje utječu na uspjeh studiranja

U nastavku istraživanja izvršena je komparativna analiza uspjeha studiranja u pogledu ostvarene prosječne ocjene na kraju studiranja i prosječnog vremena provedenog na studijama, na temelju analize uspjeha studenata na Fakultetu organizacijskih nauka u ovisnosti o njihovom statusu upisa na Fakultet (status financiranje iz državne subvencije - SBF i status samofinanciranja - SFS). Analiza uspjeha studiranja bit će napravljena u odnosu na spol studenata, tip prethodno završene srednje škole i područja iz kojega je student došao na studij, kao i na studijski program koji je student završio tijekom studija.

Na Fakultetu organizacijskih nauka prilikom upisa na prvu godinu osnovnih akademskih studija studenti se mogu opredijeliti za jedan od dva studijska programa: Informacijski sustavi i tehnologije (koji će biti referenciran kao IST) i Menadžment i organizacija (koji će biti referenciran kao MN). U odnosu na status upisa na Fakultet, tijekom analize podataka, utvrđeno je da postoji statistička značajnost u broju studenata na svakom od studijskih programa, gdje je najveći broj SBF diplomaca (566 studenata) završilo studijski program IST, što predstavlja 72 % diplomiranih na tom studijskom programu i 31,7 % u odnosu na ukupan broj studenata koji su obuhvaćeni ovim istraživanjem (Slika 1a). Istodobno, studenti koji su upisani u statusu samofinanciranja (SFS) i koji su završili studijski program MN čine 55 % studenata obuhvaćenih ovim istraživanjem, koji su završili isti studijski program. U pogledu ostvarene prosječne ocjene na kraju studija u korelaciji studijskog programa i statusa upisa na Fakultet, studenti koji su završili studijski program MN i bili u

statusu SBF ostvarili su prosječnu ocjenu studiranja 8,61, a njih slijede studenti sa studijskog programa IST koji su tijekom studiranja ostvarili prosječnu ocjenu od 8,55 u okviru statusa SBF. Kada su u pitanju studenti koji su studirali u statusu SFS, gledajući ostvarene prosječne ocjene na kraju studija, bolje rezultate ostvarili su studenti sa studijskog programa MN (prosječna ocjena 8,13), dok su najslabiji uspjeh zabilježili studenti iz statusa SFS na studijskom programu IST, kod kojih je zabilježena prosječna ocjena od 7,92 (Slika 1 b).

Slika 1

Promatrajući prosječno vrijeme provedeno na studiju u odnosu na status upisa na Fakultet, studenti sa studijskog programa IST i MN koji su upisani u statusu SBF studije su u prosjeku završavali za manje od 5 godina, odnosno za 4 godine i 8 mjeseci su završavali studenti sa studijskog programa MN, dok je studentima sa studijskog programa IST bilo potrebno u prosjeku 4 godine i 10 mjeseci. Kod studenata koji su upisani na Fakultet u statusu SFS prosječno vrijeme provedeno na studijama je preko 5 godina, gdje je najduže prosječno vrijeme studiranja zabilježeno kod studenata sa studijskog programa IST (5 godina i 4 mjeseca), dok su studenti sa studijskog programa MN u prosjeku studirali nešto kraće (5 godina i 1 mjesec). Također važno je istaknuti da diplomci sa studijskog programa IST koje su upisani u statusu SFS predstavljaju najmanje brojnu skupinu studenata obuhvaćenu ovom analizom, a koji ostvaruju najmanju prosječnu ocjenu tijekom studiranja i ujedno imaju i najduže prosječno vrijeme studiranja, dok kod studenata iz statusa SBF koji su završili studijski program MN zabilježena najbolja prosječna ocjena studiranja, a ujedno i najkraće vrijeme studiranja.

Analizirajući utjecaj spola studenta na uspjeh studiranja u odnosu na način upisa na prvu godinu osnovnih akademskih studija, može se zaključiti da su studenti oba spola koji su upisani u statusu SFS ostvarili slabiji uspjeh studiranja u odnosu na kolege koji su upisani na prvu godinu osnovnih akademskih studija u statusu SBF (Slika 2). Studenti ženskoga spola oba statusa financiranja ostvarili su bolje rezultate u pogledu indikatora uspješnosti studiranja (SFS: prosječna ocjena studija – 8,18, prosječno vrijeme studiranja – 5,08; SBF: prosječna ocjena studija - 8,72, prosječno vrijeme studiranja - 4,66) u odnosu na kolege muškoga spola koji su zabilježili nešto slabiji uspjeh (SFS: prosječna ocjena studija - 7,94, prosječno vrijeme studiranja – 5,30; SBF: prosječna ocjena studija – 8,39, prosječno vrijeme studiranja - 4,99), sa statističkom značajnošću od 0,05. Također može se zaključiti da je prosječno vrijeme studiranja kod studenata koji su upisani u statusu SBF, bez obzira na spol studenta, značajno kraće u odnosu na vrijeme potrebno studentima iz statusa SFS da završe fakultet. Promatrajući ostvarenu prosječnu ocjenu na kraju studija kod studenata koji su upisani u statusu SBF zabilježena je značajnost koja upućuje na veću prosječnu ocjenu u odnosu na studente koji su na prvu godinu osnovnih akademskih studija upisani u statusu SFS (Slika 2).

Slika 2

Sagledavajući strukturu studenata obuhvaćenih ovim istraživanjem, najveći broj studenata, odnosno 75 % studenata Fakulteta organizacijskih nauka, prethodno je završio gimnaziju. Iz srednjih ekonomskih i tehničkih škola dolazi oko 20 %, dok je 7 % prethodno pohađalo srednju ekonomsku školu, a kod tehničkih škola mogu se izdvojiti studenti koji su prethodno završili srednju tehničku školu i to njih 5,68 % i 6,86 % studenata koji su završili elektrotehničku školu. Preostalih 5,5 % studenata na Fakultet dolaze nakon završene srednje strojarske škole, srednje škole netehničkog usmjerenja ili su srednju školu završili u inozemstvu. Studenti koji će biti upisani na status SBF i SFS odabiru se na temelju prosječne ocjene ostvarene u srednjoj školi i broja bodova ostvarenih na razredbenom ispitu za upis na Fakultet. U nastavku rada stoga će biti analiziran utjecaj i ovisnost tih varijabli na indikatore uspješnosti studiranja.

Varijabla koja ima iznimno visok značaj prilikom upisa studenata na Fakultet i određivanja njihova statusa financiranja jest prosječan uspjeh koji je student ostvario tijekom prethodnoga školovanja u srednjoj školi (sagledavaju se prosječne konačne ocjene nakon svake od četiri školske godine srednjoškolske edukacije). Kao što se može zaključiti iz Slike 3 (a), u status SBF upisani su studenti koji su tijekom srednjoškolske edukacije ostvarivali odličan uspjeh (prosječna ocjena iz srednje škole je viša od 4,5), dok studenti koji su upisivani u status SFS su u srednjoj školi ostvarivali vrlo dobar uspjeh (prosječna ocjena iz srednje škole je u rasponu od 4 do 4,5). Bez obzira na status upisa, studenti koji su prethodno završili srednju strojarsku školu, imali su najvišu prosječnu ocjenu iz srednje škole i to 4,82 ako su upisani na status SBF, odnosno 4,44 kod statusa SFS. Studenti koji su upisani u SBF status, gledajući uspjeh koji su imali u srednjoj školi, kao najbolji su se pokazali studenti koji su prethodno završili srednju strojarsku školu, a njih odmah slijede studenti koji su završili srednju tehničku školu (ostvarivši prosječan uspjeh u srednjoj školi od 4,64), potom sa srednjom prosječnom ocjenom ostvarenom tijekom srednjoškolskog obrazovanja od 4,62 slijede studenti koji su završili gimnaziju ili elektrotehničku školu. Sagledavajući uspjeh studenata iz statusa SFS kroz uspjeh u srednjoj školi, kao najbolji izdvajaju se studenti iz srednje strojarske i srednje ekonomske škole sa ostvarenom prosječnom ocjenom od 4,39, odnosno 4,44, respektivno, dok ih slijede student koji su završili srednju tehničku školu (prosječna ocjena iz srednje škole 4,20) i studenti koji su završili gimnaziju (prosječna ocjena iz srednje škole 4,13) (Slika 3a).

Slika 3

Druga važna varijabla koja u bitnoj mjeri utječe na status upisa na Fakultet jest broj bodova koji su studenti ostvarili na razredbenom ispitu prilikom upisa na Fakultet, gdje se broj bodova kreće od 1 do 100. Na razredbenom ispitu, u prosjeku, najveći broj bodova ostvarili su studenti koji su prethodno završili gimnaziju (prosječan broj bodova je 71,96), a potom slijede studenti koji su završili srednju tehničku školu (prosječan broj bodova je 71,03) i srednju strojarsku školu (prosječan broj bodova

je 69,74). Srednjoškolci koji su na razredbenom ispitu u prosjeku ostvarili više od 60 bodova imali su priliku upisati se na Fakultet u statusu financiranja iz državne subvencije – status SBF (Slika 3 b). Analizirajući studente koji su upisani u statusu SFS, dobre rezultate na razredbenom ispitu ostvarili su studenti koji su prethodno završili gimnaziju (prosječan broj bodova je 41,26) i srednju elektrotehničku školu (prosječan broj bodova je 39,36), ali je bitno istaknuti, da iako su oni na statusu SFS ostvarili dobre rezultate, u odnosu na studente sa statusa SBF, to predstavlja gotovo dvostruko lošiji rezultat (Slika 3 b).

U pogledu broja studenata koji na studij Fakulteta organizacijskih nauka dolaze iz različitih regija i županija, veliku većinu čine studenti iz regije Grada Beograda i čine 54 % od ukupnog broja studenata, a potom slijede njih 25% od ukupnog broja studenata, koji su na studij došli iz Šumadije i Zapadne Srbije (odnosno iz županije Zlatibora, Raške i Morave), dok tek 5 % studenata čine oni koji su srednju školu završili u inozemstvu (Crna Gora, Bosna i Hercegovina, Kanada itd.). Na razredbenom ispitu su se kao najbolji pokazali studenti koji dolaze iz Južne i Istočne Srbije, ostvarivši prosječan broj bodova na razredbenom ispitu od 61,43, a ujedno studenti iz iste regije ostvaruju i najbolju prosječnu ocjenu ostvarenu tijekom osnovnih akademskih studija od 8,47. Sagledavajući prosječno vrijeme provedeno na studijama, najkraće vrijeme studiranja, od 4 godine i 2 mjeseca, ostvaruju studenti koji su na studij došli s Kosova, kako unutar statusa SBF, tako i ukupno (Slika 4). Studenti koji su srednju školu završili u regiji Šumadije i Zapadne Srbije ili u inozemstvu, imaju najdulje vrijeme studija unutar statusa SBF, od 4 godine i 11 mjeseci. Kod studenata koji su upisani u statusu SFS, najdulje prosječno vrijeme studiranja od 5 godina i 5 mjeseci ostvaruju studenti koji su na studij došli iz Vojvodine, dok su najkraće vrijeme studiranja unutar studenata u statusu SFS ostvarili studenti iz beogradske regije (5 godina i 1 mjesec) – Slika 4.

Slika 4

Utjecaj statusa upisa na performanse uspješnosti studiranja

U cilju otkrivanja zakonitosti, pravilnosti u podacima o studentima koji su upisali osnovne akademske studije u školskoj 2004./2005. godini i završili ih do studenog 2013. godine, a koristeći koncept Binomna logističke regresije, utvrđeno je da postoji statistička značajnost između statusa upisa na Fakultet i ovisnih varijabli koje upućuju na uspjeh studenata u srednjoj školi, područja iz kojega student dolazi na studij, tipa prethodno završene srednje škole, broja bodova na razredbenom ispitu, studijskoga programa, prosječne ocjene ostvarene tijekom studija (GPA) i prosječnog vremena provedenog na studiju ($\chi^2_{(5, N=1787)}=1318,606, p<0,01$) .

Kod ispitivanje ovisnosti i utjecaja uspjeha studenata na Fakultetu, od osam početnih ulaznih varijabli (Regija iz koje je student došao na studij, Tip završene srednje škole, Uspjeh u srednjoj školi, Broj bodova na prijemnom ispitu, Studijski program, Prosječna ocjena studija, Prosječno vrijeme studiranja i Spol studenata), pet varijabli se izdvojilo

putem regresijskog modela u 4 koraka, koji upućuje na značajnu korelaciju u odnosu na status uspjeha na Fakultetu i uspjeh studiranja, gdje je pregled varijabli i njihova finalna značajnost predstavljena u Tablici 1. Tijekom primjene Binomna logističke regresije (poštovan je minimalni broj slučajeva po svakoj od neovisnih varijabli, a također testirana je i potvrđena normalnosti, linearnost i homogenosti varijance, iako nije bilo nužnosti za tim analizama shodno istraživanju Hosmer i sur., 2013), u promatranom skupu varijabli, kod 3 varijable nije postojala statistička značajnost, te su zbog toga te varijable isključene iz daljnje analize i to je izvršeno po sljedećem redoslijedu: Spol studenata ($p = 0,544$), Regija iz koje je student došao na studije ($p = 0,344$), Tip završene srednje škole ($p = 0,428$).

Tablica 1

Kao što je vidljivo, u skladu s rezultatima prezentiranim u prethodnoj tablici (Tablica 1) prve četiri varijable (Broj bodova na prijemnom ispitu, Prosječna ocjena studija, Uspjeh u srednjoj školi, Prosječno vrijeme studiranja) značajne su za definiranje uspjeha studenata u okviru statusa SBF ($\exp(B) > 1$), dok varijabla Studijski program ima značajan utjecaj na definiranje uspjeha studenata unutar statusa SFS.

Tijekom daljnje analize podataka primijenjena je CATPCA (*Principal Components Analysis for Categorical Data*) analiza podataka s ciljem utvrđivanja adekvatnog način integracije informacija koje su sadržane u originalnim varijablama unutar manjeg skupa, koje predstavljaju nove kompozitne varijable, a koje trebaju biti reprezentativni predstavnici originalnih varijabli kao podskup njihovih podataka, s minimalnim gubitkom informacija. U podatcima o uspjehu pet generacija studenata s osnovnih akademskih studija s Fakulteta organizacijskih nauka, uz primjenu faktorske analize (*Factor analysis*) definirane su skupine s tri, odnosno četiri varijable koje na statistički značajan način utječu na ukupan uspjeh studiranja ovisno o stanju upisa na Fakultet, gdje su rezultati za status SBF i SFS respektivno prikazani u Tablici 2.

Tablica 2

Kod studenata koji su upisani u statusu SBF izdvojila su se 4 podskupa varijabli, dok je kod studenata u statusu SFS izdvojeno 3 podskupa varijabli koje na statistički značajan način determiniraju ukupan uspjeh studenata. Varijable koje se nalaze u drugom podskupu, od iznimne su važnosti za određivanje uspjeha unutar oba statusa. Kod studenata koji su u statusu SBF prvi podskup najznačajnijih varijabli čine sljedeće varijable: Prosječno vrijeme studiranja, Broj bodova na prijemnom ispitu i Prosječna ocjena studija; dok kod studenata koji su u statusu SFS prvi podskup najznačajnijih varijabli čine sljedeće varijable: Prosječno vrijeme studiranja, Broj bodova na prijemnom ispitu, Prosječna ocjena studija i Uspjeh u srednjoj školi. Sagledavajući varijable koje se nalaze u prvom podskupu varijabli kod studenata po oba statusa, može se primijetiti sličnost varijabli koje su ključne za praćenje i definiranje ukupnog uspjeha studiranja.

U okviru drugog podskupa varijabli, kod studenata koji studiraju u statusu SBF, kao varijable putem kojih se može učinkovito odrediti uspjeh studiranja, izdvajaju se: Spol studenta i Studijski program; dok treći podskup sadrži samo jednu varijablu: Tip završene srednje škole; a u četvrtom podskupu varijabli se nalaze varijable koje predstavljaju relaciju studenta sa srednjom školom (Uspjeh u srednjoj školi i Regija iz kojeg je student došao na studij). Uspjeh studenata koji studiraju u SFS statusu, pored varijabli koje se nalaze u prvom podskupu varijabli, može se definirati i putem sljedećih varijabli: Spol studenta i Studijski program koje se nalaze u drugom podskupu značajnih varijabli; ili putem treće podskupine varijabli koju čine Regija iz kojeg je student došao na studij i Tip završene srednje škole.

Zaključak

U ovom radu, s ciljem bolje organizacije prikupljenoga znanja i informacija o studentima i njihovu uspjehu tijekom sveučilišnog obrazovanja, uz podršku metoda i tehnika otkrivanja zakonitosti u podacima, izloženi su zaključci o utjecaju načina upisa na Fakultet na performanse uspjeha studiranja, prije svega u pogledu ostvarene prosječne ocjene i duljine studiranja. Rezultati istraživanja upućuju na to da postoje razlike u pogledu ostvarenih izvedbi uspjeha studiranja kod studenata koji su upisani na studij u statusu financiranja iz državne subvencije (SBF) i statusu samofinanciranja (SFS).

Analiza uspjeha studenata tijekom visokoškolske edukacije, koja je prikazana u ovom radu, pokazuje da studenti koji su na Fakultet upisani u statusu financiranja iz državne subvencije ostvaruju bolji uspjeh tijekom studiranja, što se ogleda u ostvarenim boljim prosječnim ocjenama studiranja (viša prosječna ocjena studiranja) i vremenu potrebnom za završetak studija (kraće prosječno vrijeme završetka Fakulteta), u odnosu na studente koji su upisani u statusu samofinanciranja. Pretpostavljajući da studeni nakon završene srednje škole, a prilikom upisa na Fakultet posjeduju približno isti stupanj znanja, kao jedan od mogućih pravaca unapređenja visokoškolskog obrazovnog sustava, vidljiv je u dodatnoj mogućnosti poboljšanja i unapređenja uspjeha studenata koji su upisani u statusu samofinanciranja. Studenti sa studijskog programa Menadžment i organizacija postigli su bolji akademski uspjeh kako u pogledu ostvarene prosječne ocjene studiranja tako i potrebnoga kraćeg prosječnog vremena za završetak Fakulteta u odnosu na kolege sa studijskoga programa Informacijski sustavi i tehnologije, bez obzira na to jesu li upisani u statusu financiranja na teret državne subvencije ili statusu samofinanciranja. Najkraće vrijeme završetka studija zabilježeno je kod studenata koji su na studij došli s Kosova, dok su najbolju prosječnu ocjenu studiranja ostvarili studenti iz Južne i Istočne Srbije, unatoč tome što su najbrojniji studenti oni koji su srednju školu završili u beogradskome području.

Budući pravci razvoja i istraživanja, prije svega u pogledu korištenja naprednih koncepata otkrivanja zakonitosti u podacima iz područja visokoškolske edukacije, obuhvaćaju uključivanje većeg broja ulaznih varijabli, kako onih koji se izravno odnose

na studije tako i socioekonomskih te demografskih pokazatelja, njihovu komparativnu analizu, te razvoj modela za predviđanje uspjeha studiranja utemeljenoga na varijablama koje su analizirane u okviru ovoga rada.

Zahvala

Ovo istraživanje dijelom je financiralo Ministarstvo prosvjete i nauke Republike Srbije kao dio projekta tehnološkoga razvoja (broj projekta ID III 47003).